卷积神经网络方法在岛礁类海啸波水动力特性演变的应用

摘要：快速预测和评估海啸是预防海洋灾害工作中的重要部分，对于海洋工程和人民生命财产安全具有重要意义。本文以一维卷积神经网络(1-Dimensional Convolutional Neural Network, CONV1D)为基础,构建岛礁地形的类海啸波水动力特性演变模型。通过输入类海啸波波高时程曲线的观测值，得到岛礁指定地点的水位淹没时程曲线，实现时间序列到时间序列的预测，达到预防海洋灾害的目的。结果显示，对类海啸波到达时间预测的平均误差为 0.71%，最大水位高度预测的平均误差为 6.99%，CONV1D 得到的岛礁地形类海啸波水动力特性与数值结果吻合较好。

关键词：深度学习 卷积神经网络 海啸预测 水动力特性 时间序列

Application of Convolutional Neural Network Methods in the Evolution of Hydrodynamic Characteristics of Tsunamis like-wave over fringing reef

Abstract: Rapid and accurate tsunami is an important part of Marine disaster prevention work, which is of great significance to Marine engineering and people's life and property safety. In this paper, based on 1-Dimensional Convolutional Neural Network (CONV1D), the evolution model of tsunami-like hydrodynamic characteristics of reef topography is constructed. By inputting observed values of wave heights resembling tsunami waves, the water inundation time series curves for specified locations on islands and reefs are generated. This achieves a prediction from one time series to another, serving the purpose of marine disaster prevention. The results indicate that the average error in predicting the arrival time of tsunami-like waves is 0.71%, and the average error in predicting maximum water levels is 6.99%. The hydrodynamic characteristics of island and reef terrains resembling tsunami waves obtained through CONV1D exhibit a strong alignment with numerical results.

Keywords: Deep learning, Convolutional neural network, Tsunami prediction, Hydrodynamic characteristics, Times series

1 前言

中国南海，是我国“建设海洋强国”战略目标的重要一环，对于国家安全和经济建设具有举足轻重的意义。自 2013 年来，我国对于南海珊瑚岛礁开发的步伐加快，美济礁、渚碧礁、永暑礁等地区填礁造陆、填海造陆等工程活动日益增多（李庆功 等，2014；姚宇 等，2019），由于该海域位于亚欧、太平洋和印度-澳大利亚板块的交汇地带，包含马尼拉海沟、苏禄海沟和苏拉威西海沟等潜在海啸源，因此风暴潮、海啸等海洋极端天气引起的极端波浪事件，是工程建设必须

收稿日期：　修订日期：

基金项目：

作者简介：

Received date: Revised date:

Foundation item:

Corresponding author:

要考虑重要因素。提前对海啸等自然灾害进行预测和评估，是保护人民的生命和财产安全重要措施（包澄澜, 2005）。

中国海区域海啸预警中心主要使用德国 SeisComP3 和美国 Antelope 地震监测处理系统，传统的海啸预警方法有其技术方法的局限性，2011 年日本东北海啸因未能正确评估海啸灾害，造成了巨大经济损失和人员伤亡（刘烨等，2015；徐志国等，2022）。更快更准确的海啸预警手段引起人们重视，神经网络在此之前已初步具备预警能力，在此之后更多更完善的神经网络也得到实现。然而传统的神经网在海啸预警模拟时因其庞大的计算数据和复杂的非线性过程，使得计算成本变得高昂，实时监测的海啸预警仍是巨大挑战（董杰 等，2021; Han et al，2021）。

计算机算力的快速提升，为深度学习发展提供了必要条件，2012 年 Hinton 小组发明的深度卷积神经网络（CNN）AlexNet（Krizhevshky et al, 2012）首先在图像处理方面取得成功，随后深度学习在其他各领域引起广泛的研究。在处理时间序列问题上，循环神经网络（RNN）和长短期记忆神经网络（LSTM）得到广泛应用（Graves , 2012）。2015 年 Kiranyaz 等设计出一维卷积神经网络(CONV1D)在很短的时间内对心电图进行分类，成为了最先进信号处理应用程序（Kiranyaz et al, 2015）。CNN-LSTM 混合模型可以解决非连续数据的问题（陆继翔 等, 2019）。2021 年 Makinoshima 等构建的一维卷积神经网络模型使用远海观测数据进行陆地预警（Makinoshima et al, 2021），它区别于传统的时间预测方法—通过前几个时刻的数据推测下一个时刻数据（翁少佳 等，2023），实现观测数据到海啸洪水预测的时间序列到时间序列预测，当海啸发生时，可以立即、准确地预测指定地点的海啸淹没时间序列。

本文构建时间序列到时间序列的一维卷积神经网络海啸预警模型，使用数值模拟方法得到类海啸波在岛礁地形的传播演变数据，经过训练精准预测岛礁礁坪的某一位置海啸来临时的时间序列变化。CON1VD 由于其较低的计算复杂度，适合实时和低成本的预测，同时为海洋环境和海洋工程的研究提供新思路和新方法，拓展深度机器学习技术的应用领域和方.推动机器学习技术和海洋科学的交叉发展，促进科技创新和发展。

2 模型验证

关于海啸数值模拟方法，前人提供了许多可靠的方法，本文是基于非静压单相流模型 NHWAVE，采用 Qu 等（Qu et al, 2017; Qu et al, 2021）提出的参数化类海啸波形，建立高精度数值波浪水槽，模拟类海啸波在岛礁地形上的水动力学过程。参考刘等(Liu et al,2021)进行数值的模拟验证。实验数据源于 Roeber 等(Roeber et al 2012)在海啸盆地建立的波浪水槽物理实验,我们布置的二维水槽数值模型的计算域布置与 Roeber 物理实验的模型布置大体相同，具体布置如图 1 所示，左侧计算域入口为造波边界，右侧出口为固壁边界，总长度为 50 m，礁前斜坡坡度为 1:5，礁坪长度为 28 m，分布 11 个水位测点(WG01-WG11)， x 方向为海啸波传播方向，网格大小 dx=0.05 m；z 方向为水深方向，共设置 20 层网格。使用非静压模型验证入射波高为 0.5 m，水深为 1 m，礁坪水深为 0 m，远海水深为 1 m，共 14 个测点 Roeber 等的不透水岛礁物理实验。验证结果如图 2 所示。通过对比可看出，模拟结果与实验结果有较好的吻合度。

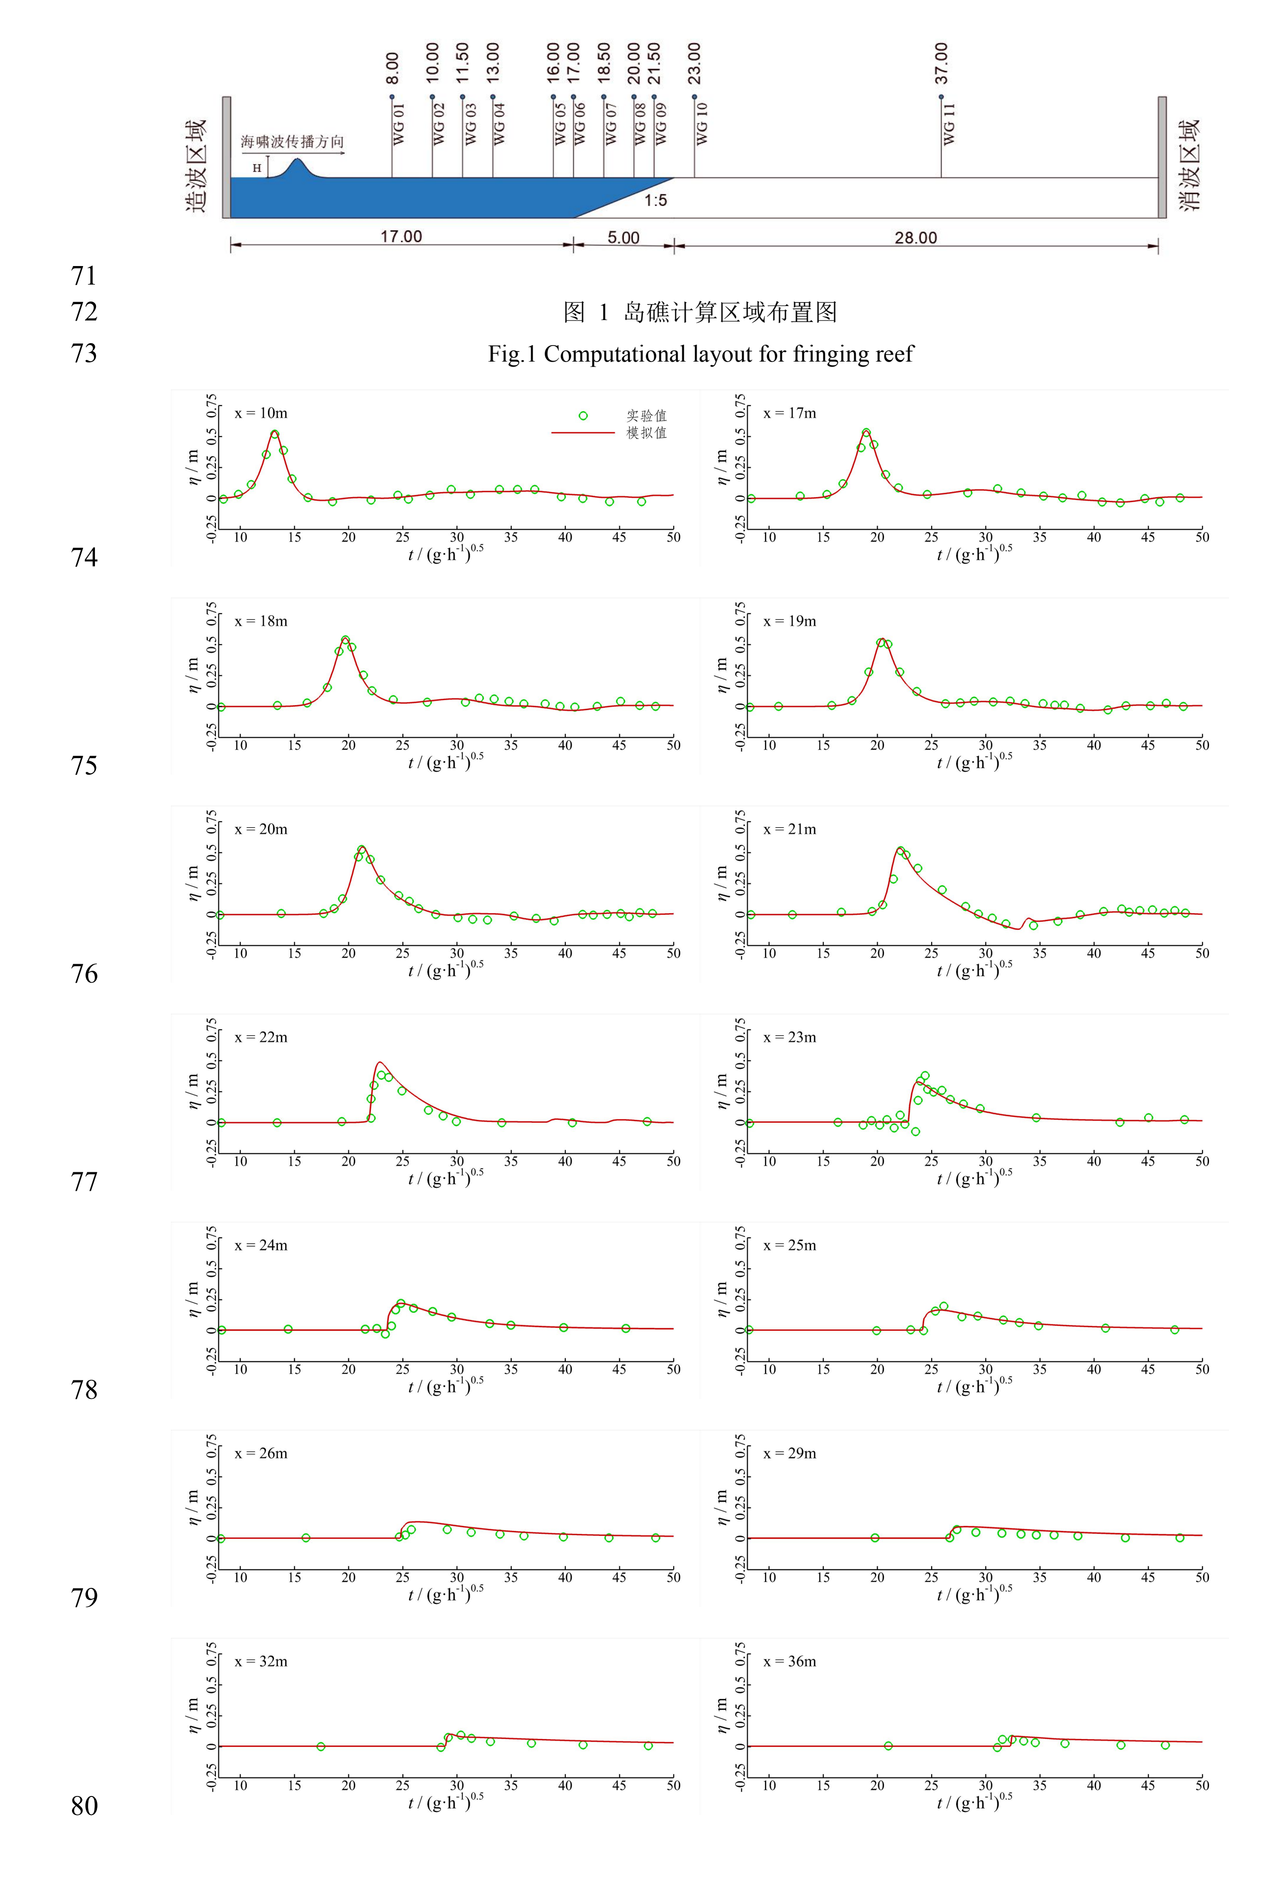


图 1 岛礁计算区域布置图

Fig.1 Computational layout for fringing reef

图 2 不同测点水面高程的时间序列（H=1.0m）

Fig.2 Time series of water elevation at different wave gauges (H= 1.0m)

3 数据集

图 3 为基于 CONV1D 的类海啸波神经网络模型的示意图。首先使用 NHWAVE 进行了 117 次类海啸波在岛礁地形传播演变的数值模拟，作为 CONVID 的数据集,其中包括 106 组训练集和 11 组测试集。训练集数据是模型学习的样本，使模型能够从输入特征中学习到数据的模式、关系和规律，从而能够在未见过的数据上进行泛化。测试集是用于评估机器学习模型性能和泛化能力的一组数据样本的集合，用于评估模型在未见过的数据上的表现。在数值模拟中，设置不同的初始类海啸波波高，最小波高 0.20m 和最大波高 0.78m。等间隔选取初始波高为 0.25m、0.30m、0.35m、0.40m、0.45m、0.50m、0.55m、0.60m、0.65m、0.70m 和 0.75m 的类海啸波作为测试集，保证其具有独立性、代表性、标签或目标输出、足够数量等性质。

类海啸波的采样频率为 0.02Hz，共收集了 16 秒类海啸波在岛礁地形的水动力特性传播演变过程，使用 10 个位置（WG01-WG10）的水位测点作为 CONVID 的多时间序列数据输入，预测指定岛礁位置（WG11）的类海啸波的水动力特性演变过程，并将类海啸波观测时长分为 5s、6s、7s、8s 和 9s 五种。

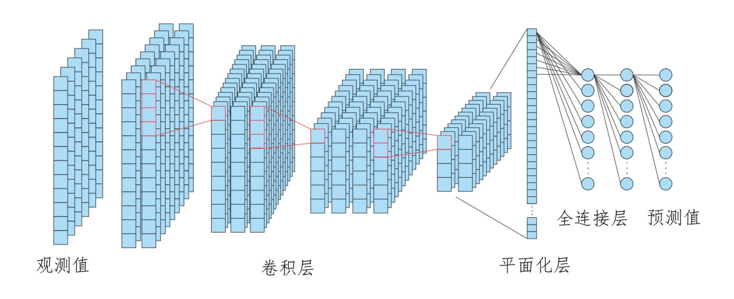


图 3 卷积神经网络结构示意图

Fig.3 Convolutional Neural Network Architecture Diagram

4 网络配置

CONV1D 主要由十二层神经网络组成，其中卷积层包括六个一维卷积层和三个池化层组成，最后是三个全连接层。每个一维卷积层之后都有一个 Leaky Relu 激活函数层(Maas et al, 2013)，参数 Negative slope 为 0.01。在最后一层全连接层前加入随机丢弃层，丢弃率为 0.5，表示每次训练输出前使用 50%特征数进行全连接，来防止过度拟合发生（Nitish et al,2014）。在卷积层中，设置了三种卷积核，分别为 7、5、3，移动步长为 1，通过填充的方法使得卷积后的序列长度不发生变化，每三层卷积层后设置一层最大池化层进行特征值数量的优化。对于 5s、6s、7s、8s 和 9s 五种观测时长，只有卷积后得到特征的数量有所不同，较长的观测周期会得更多的学习参数见表 1。在整个训练过程中使用模拟波形和预测波形的均方误差（MSE）作为损失函数，使用 Adam 优化器（Kingma et al，2014）对神经网络中的权重进行优化，将损失降低到最小，学习率为 0.0002，其他参数使用默认值。在 Pycharm 平台上基于 pytorch 框架进行模型搭建，共进行 8000 次训练，使用 i9-129000hx 处理器和 4060 系显卡完成训练大概需要 60 分钟。

5 训练结果

CONV1D 训练结束后，我们使用测试集的 11 个数值模拟结果对该模型进行评测。表 1 为不同观测时长评估类海啸波的模型参数量和需要的时间。其中 T 为不同观测时长,N 为构建模型时

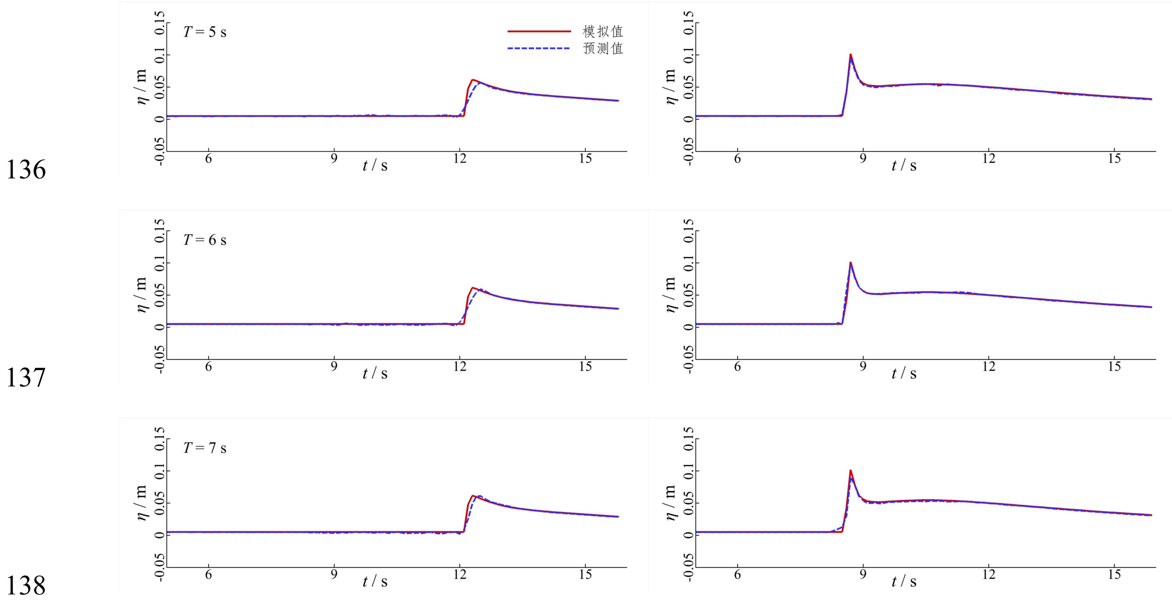
所需要的参数量,T_P为预测需要的时间。由表 1 可知对于较长的观测时间，需要使用更多的参数。1s 观测值的增加使参数的数量增加了 25600，主要是由于卷积层后全连接层的尺寸较大，其训练时间会相应增加,预测所用时间也有增加的趋势，实际时间由计算机算力决定。使用 CON1VD 进行海啸评估的计算时间只有不到 0.1 秒，这种方法比传统海啸预警机制和数值模拟的方法的快得多，而且需要计算资源更少。从上述数据可知，CONV1D 生成岛礁测点水位时程曲线的效率很高，可以迅速的得到类海啸波水动力特性演变过程，进而评估和预测海啸。在实现中，这种方法可以实现对海啸等极端波浪的实时监测。

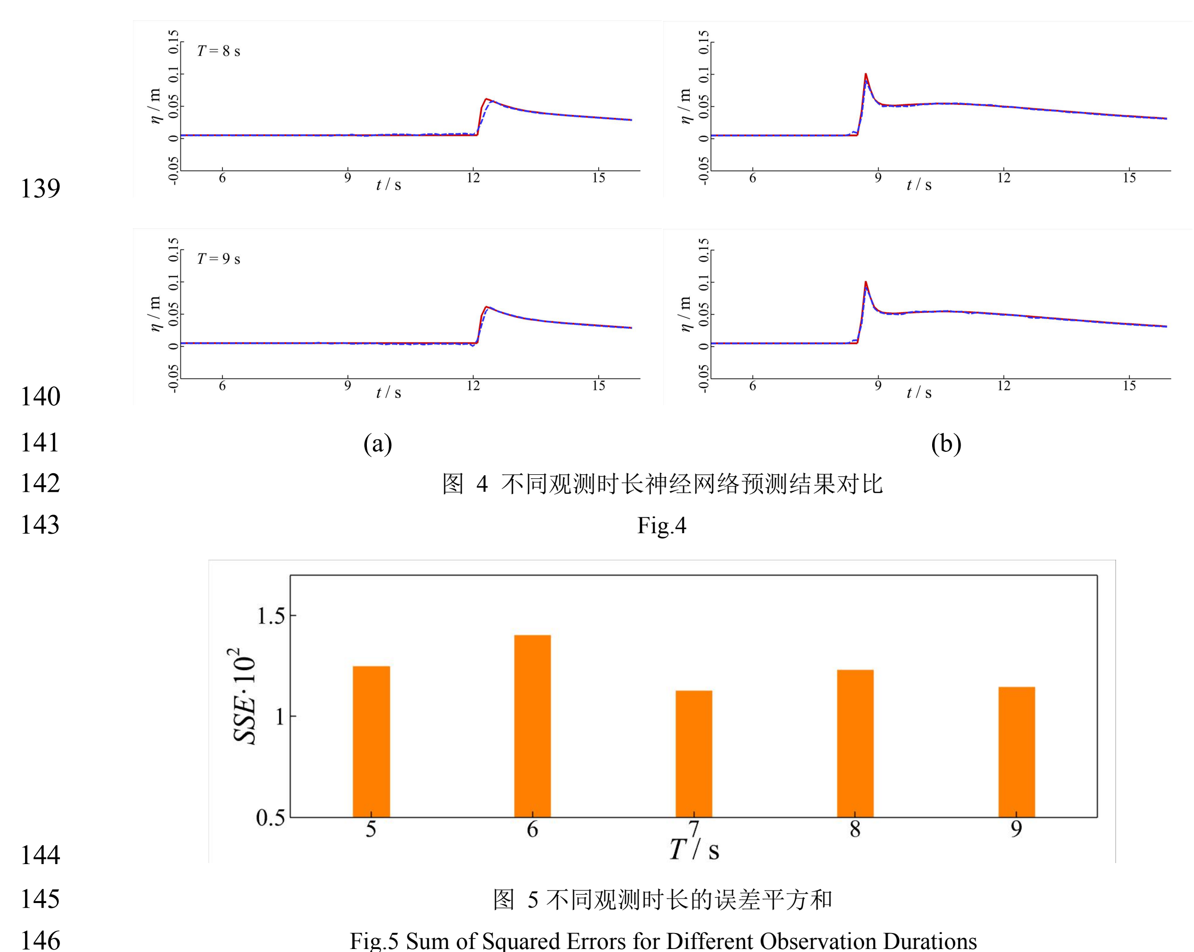
表 1 不同观测时长模型的参数量和预测所用时间

Table.1 Number of parameters and prediction time used for different observation duration models

观测时长/*T*(s)	参数量/*N*	预测所用时间/T_p (s)
5	161110	0.0164
6	186710	0.0175
7	212310	0.0182
8	237910	0.0201
9	263510	0.0175

图 4 为五种不同观测时长时程曲线结果对比，其中图 4（a）和图 4（b）的初始类海啸波波高分别为 *H*=0.30m 和 *H*=0.70m。由图可知 CONV1D 预测在五种不同观测时长下的结果和数值模拟结果都可以较好的吻合，*H*=0.30m 的类海啸波随着观测时长的增加，WG11 测点的水位的时程曲线会更加吻合；*H*=0.70m 的类海啸波随时观测时长的增加，出现到达时间提前和最大水位预测不足的问题，可能是由于参数的增加，导致模型出现了过拟合问题。图 5 为不同的观测时长产生的误差平方和（*SSE*），由图 4 和图 5 可知，不同观测时长模型的误差平方和相差较小，在 5 秒的观测时长下可以达到评估类海啸波水动力特性的要求，同时表现出 CONV1D 较强的稳定性和泛化能力。





(a) (b)

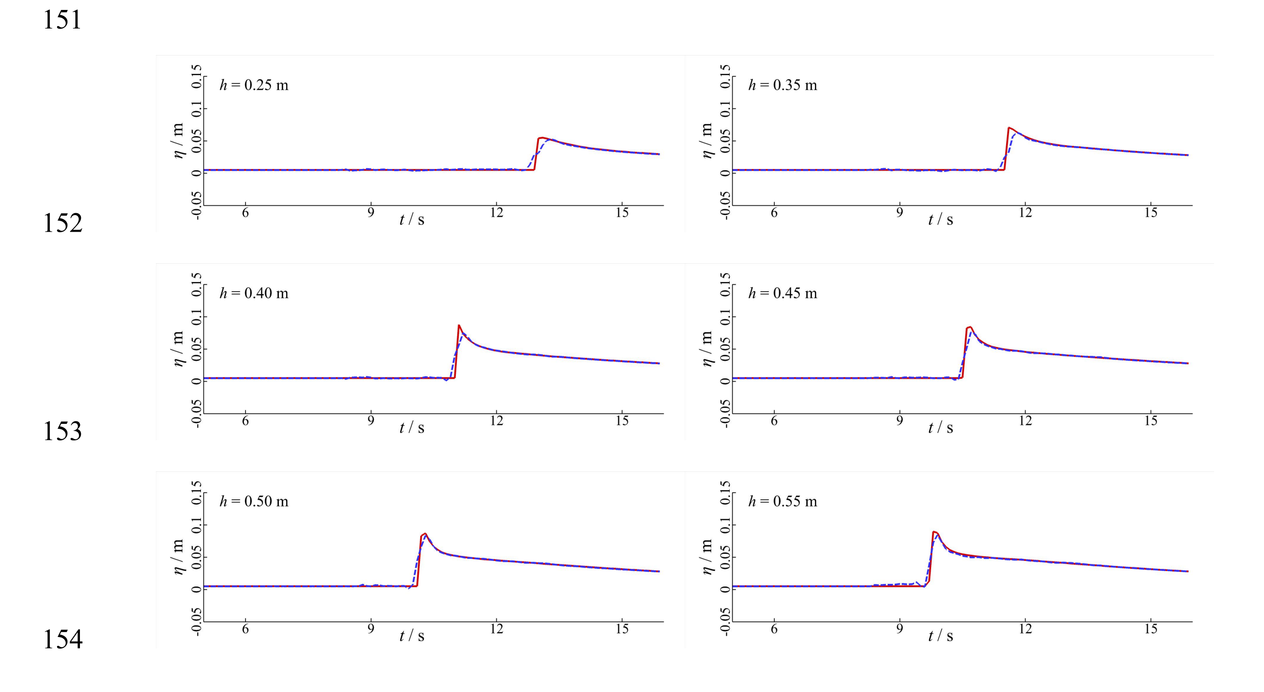
图 4 不同观测时长神经网络预测结果对比

Fig.4

图 5 不同观测时长的误差平方和

Fig.5 Sum of Squared Errors for Different Observation Durations

图 6 为在六秒观测时长下不同波高的预测结果对比。由图可知，随着类海啸波初始波高变大，测点水位的时程曲线特征特征更明显、特征值更多，因此 CONV1D 计算准确度更高，可以更好的展现类海啸波在到岛礁地形的水动力特性传播演变过程。



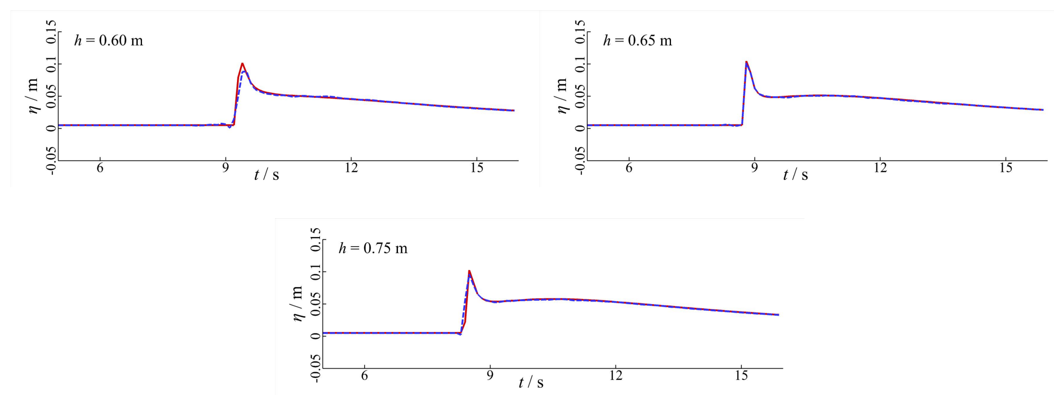


图 6 六秒观测时长下不同波高预测结果对比

Fig.6 Comparison of Different Wave Height Predictions under a 6-second Observation Duration"

为了进一步评估模型预测性能，分析以下两个指标：类海啸波到达礁坪测点的时间和该测点的最大水位。选取五种观测时长中误差平方和最大的 T=6s 模型进行分析，如表 2 所示，其中 H 为类海啸波初始波高、η_{ob} 为 WG11 观测水位、η_{p} 为 WG11 预测水位、E_{η} 为水位误差、t_{ob} 为 wg11 观测时间、t_{p} 为预测时间、E_{t} 为时间误差。

由表 2 可知，该模型出现的最高水位的最大误差为 14.46%、最小误差为 2.64%、最高水位平均误差为 6.99%; 到达时间最大误差为 1.709%、最小误差为 0%，平均误差 0.71%。图 7 为不同初始波高的最大水位和到达时间误差散点图，由图可知最大水位的误差波动较大，时间误差波动较小且误差很小，两者都呈现出有规律的波动。通过表 2 和图 7 可知，类海啸波的水动力特特性难以精准的预测，需要构建复杂度更高的 CONV1D 模型，但是该模型评估海啸到达时间的可信度很高。

表 2 六秒观测时长下不同波高的最高水位和到达时间

Table.2 Maximum Water Level and Arrival Time of Different Wave Heights under a 6-second Observation Duration

H/m	η_{ob}/m	η_{p}/m	E_{η}/%	t_{ob}/s	t_{p}/s	E_{t}/%
0.25	0.0550	0.0527	4.12	13.20	13.40	1.515
0.30	0.0616	0.0592	4.02	12.4	12.6	1.612
0.35	0.0706	0.0629	10.91	11.7	11.9	1.709
0.40	0.0878	0.0751	14.46	11.2	11.3	0.892
0.45	0.0843	0.7066	9.13	10.8	10.8	0
0.50	0.0872	0.0836	4.12	10.4	10.4	0
0.55	0.0897	0.0849	5.35	9.9	10.0	1.010
0.60	0.1018	0.0884	12.34	9.5	9.6	0.105
0.65	0.1046	0.1016	2.86	8.9	8.9	0
0.70	0.1049	0.0991	2.64	8.8	8.8	0
0.75	0.1025	0.0964	5.85	8.6	8.6	0

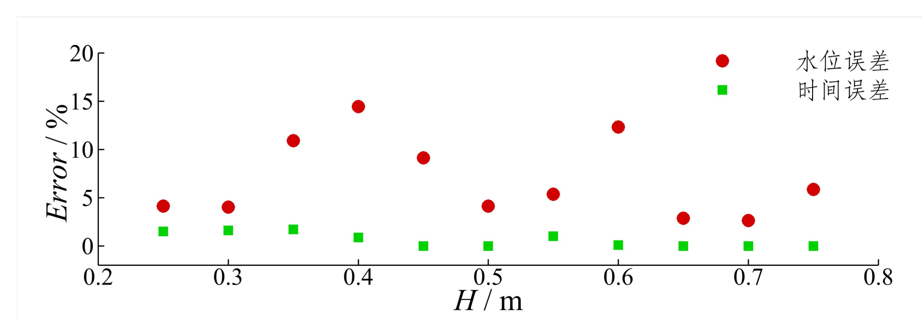


图 7 六秒观测时长下不同波高的最高水位误差和到达时间误差

Fig.7 Error in Maximum Water Level and Arrival Time for Different Wave Heights under a 6-second Observation Duration

6 结论

本文通过构建 CONC1D 模型，实现类海啸波在岛礁地形水动力特性演变过程的预测。该模型得到的类海啸波预测结果和数值模拟结果基本吻合，对于不同观测时长得到的结果基本一致。在最大的误差平方和的情况下，模型评估岛礁指定地点的最大水位误差平均值为 6.99%，到达时间误差平均值仅为 0.71%。CONV1D 只需要较少的计算资源获得较高的计算效率，可以提前精准获取波浪信息，达到预防灾害和保护人民生命财产安的目的。

参考文献

李庆功, 周忠菲, 苏浩, 等, 2014. 中国南海安全的战略思考[J]. 科学决策, No.208(11):1-51.
LI, ZHONG ZHOUFEI, SU HAO, et al, 2014. Strategic thinking on the Security of the South China Sea [J]. Scientific Decision-Making, No.208 (11): 1-51(in Chinese with English abstract).

姚宇, 2019. 珊瑚礁海岸水动力学问题研究综述[J]. 水科学进展, 30(01):139-152.
YAO YU,2019. Review of hydrodynamic issues along the coral reef coast [J]. Progress in Water Science, 30 (01): 139-152(in Chinese with English abstract).

包澄澜, 2005. 海啸灾害及其预警系统[J].国际地震动态, (01):14-18.
BAO CHENGLAN, 2005. Tsunami disaster and its early warning system [J]. Recent Developments in World Seismology, (01): 14-18(in Chinese with English abstract).

刘桦, 赵曦, 王本龙, 等, 2015. 海啸数值模拟与南海海啸预警方法[J]. 力学季刊, 36(03):351-369.
LIU YE, ZHAO XI, WANG BEN LONG, et al. Numerical Simulation of Tsunami and Tsunami Warning Methods for South China Sea Region[J].Chinese quarterly of mechanics, 36(03):351-369(in Chinese with English abstract).

徐志国, 史健宇, 李宏伟, 等, 2022. 南中国海区域海啸预警中心地震监测系统[J]. 地震科学进展, 52(10):473-481.XUE ZHIGUO, SHI JIANYU, LI HONGWEI, et al, 2022. The earthquake monitoring system in the South China Sea Tsunami Advisory Center[J]. Progress in earthquake sciences, 52(10):473-481(in Chinese with English abstract).

董杰, 田士政, 武文, 等, 2019. 全球海啸预警系统发展及其对我国的启示[J]. 海洋通报, 38(4): 368-378. DONG JIE, TIAN SHIZHENG, WU WEN, et al, 2019. The development of global tsunami warning systems and their enlightenments to China[J]. Marine science bulletin SCIENCE BULLETIN, 38(4): 368-378(in Chinese with English abstract).

陆继翔, 张琪培, 杨志宏, 等, 2019 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化, 43(8): 131-137(in Chinese with English abstract).

翁少佳,蔡锦海,庞运禧,等, 2023.卷积神经网络在近岸表层海温预报中的应用[J/OL].热带海洋学报:1-10. Application of convolutional neural network to sea surface temperature prediction in the coastal waters[J/OL]. Journal of Tropical Oceanography:1-10(in Chinese with English abstract).

刘铁威, 屈科, 黄竞萱, 等, 2021. 孤立波在透水岸礁上水动力特性数值模拟研究[J].水动力学研究与进展(A 辑), 36(02):180-191.LIU TEIWEI, QU KE, HUANG JINGXUAN, et al, 2021. Numerical investigation of hydrodyn amic characteristics of solitary[J]. Chanese journal of hydrodynamics(A), 36(02):180-191(in Chinese with English abstract).

Han Zhongyang, Zhao Jun, HENRY, et al, 2021. A Review of Deep Learning Models for Time Series Prediction[J]. IEEE Sensors Journal 12(6): 7833-7848

KRIZHEVSKY A, SUTSKEVER I, Hinton G E, 2012. Imagenet classification with deep convolutional neural networks[J]. Advances in neural information processing systems.25.

GRAVES A, 2012. Long short-term memory[J]. Supervised sequence labelling with recurrent neural networks, 37-45.

KIRANYAZ S, Ince T, HAMIL R, et al, 2015. Convolutional neural networks for patient-specific ECG classification[C]// 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, 2608-2611.

MAKINOSHIMA F, OISHI Y, YAMAZAK T, et al 2021. Early forecasting of tsunami inundation from tsunami and geodetic observation data with convolutional neural networks[J]. Nature communications, 2021, 12(1): 2253.

QU KE, REN XING YUE, KRAATZ S, 2017. Numerical investigation of tsunami-like wave hydrodynamic characteristics and its comparison with solitary wave[J]. Applied Ocean Research,63: 36-48.

QU KE, REN XINGYUE, KRAATZ, et al 2021. Numerical analysis of tsunami-like wave impact on horizontal cylinders[J]. Ocean Engineering, 145:316-33.

Roeber V, Cheung K F, 2012. Boussinesq-type model for energetic breaking waves in fringing reef environments[J]. Coastal Engineering, 70: 1-20.

MAAS A L, HANNUN A Y, Ng A Y, 2013. Rectifier nonlinearities improve neural network acoustic models[C]// Proc. Icml.30(1): 3.

NITISH S, GEOFFREY H, ALEX K, et al 2014. Dropout: A Simple Way to Prevent Neural Networks from Over-fitting[J]. *The Journal of Machine Learning Research*, 15(1) 1929–1958.

KINGMA D P, Ba J, 2014. Adam: A method for stochastic optimization[J]. arXiv preprint arXiv:1412.6980.